

基于 GAT 和 TextCNN 的罪名预测研究

吴晗

山东建筑大学法学院, 山东 济南 250101

摘 要 : 罪名预测作为实现智慧司法的重要任务之一,旨在根据有关犯罪行为的事实描述来预测所成立的罪名。为了更高效、准确地进行罪名预测,本文提出了一个名为 GAT-Cross-TextCNN 的罪名预测模型。首先,将案件构建出图结构的数据,然后利用图注意力网络 GAT 学习得到整个图的结构表示;再利用文本卷积神经网络 TextCNN 学习整个案例的文本语义表示。最后,将学习到的结构表示和语义表示利用交叉注意力机制进行特征融合,并最终得到整个案例的特征向量。最后,使用 Softmax 文本分类器进行罪名预测,得到案例所属的罪名。在 CAIL2018 罪名预测数据集上的实验结果表明,TextCNN-GAT-CrossAttention 模型的准确率、召回率和 F1 值分别达到了 0.9416、0.939、0.9398,优于基线模型,验证了本文所提出的方法在罪名预测任务上的性能。

关 键 词 : 罪名预测; 图注意力网络; TextCNN; 交叉注意力机制

Research on Charge Prediction Based on GAT and TextCNN

Wu Han

School of Law, Shandong Jianzhu University, Jinan, Shandong 250101

Abstract : As one of the important tasks to achieve smart justice, crime prediction aims to predict the crime according to the factual description of criminal acts. In order to predict the crime more efficiently and accurately, this paper proposes a crime prediction model named gat cross textcnn. Firstly, the case is constructed into the data of graph structure, and then the structure representation of the whole graph is obtained by using graph attention network gat learning; Then the text convolution neural network textcnn is used to learn the text semantic representation of the whole case. Finally, the learned structural and semantic representations are fused using the cross attention mechanism, and finally the feature vector of the whole case is obtained. Finally, we use the softmax text classifier to predict the charges, and get the charges of the case. The experimental results on cail2018 dataset show that the accuracy, recall and F1 value of textcnn gat crossattention model are 0.9416, 0.939 and 0.9398 respectively, which are superior to the baseline model, and verify the performance of the proposed method in the crime prediction task.

Keywords : crime prediction; graph attention networks; TextCNN; cross attention mechanism

近年来,随着人工智能技术的不断发展,其在法律领域的应用也逐渐增多。法律判决预测是实现智慧司法的核心任务,罪名预测更是作为法律判决预测的子任务之一。如图1所示,罪名预测任务的主要目标是当给定关于犯罪事实的文本描述时,模型自动给出罪名的预测结果。

罪名预测技术的实现不仅可以辅助法官办案,有助于减轻法官的办案负担;而且也可以为案件的当事人提供有关罪名的信息,有助于当事人更清楚地了解案件的信息;最后还可以为社会公众提供一个平台,有助于减轻社会公众的诉讼成本。

本文提出了一种基于图注意力神经网络(Graph Attention Network, GAT)和文本卷积神经网络(TextCNN)的罪名预测模型: GAT-Cross-TextCNN。首先,构建每一个案例的图结构数据,然后利用图注意力神经网络获取案例图的结构信息表示;利用文本卷积神经网络获取案例文本的语义信息表示,最后使用交叉注意力机制将上述得到的两个特征向量进行融合,并将其输出到全连接层进行输出相应的预测罪名。在实验部分,与基线模型相比, GAT-Cross-TextCNN 模型能显著提高罪名预测性能,验证了本文所提出方法的有效性。

2023年7月13日晚上,一名下班回家的男士李四正在路上独自行走。张三见其独自一人,便悄悄跟在李四后面,等到李四走到一个没人的地方,张三便趁其不备,抢走了李四的手提包。李四见状报警,两小时后张三被抓。

文本
输入

模型

罪名
预测

抢夺罪

> 图1 罪名预测任务

一、相关工作

在早期工作中，由于缺少大量的标注数据，研究者们围绕使用数学或统计方法分析特定的案例，试图从历史案例中找出其中的规律。Kort 等利用统计学模型分析大量的历史案例来预测美国联邦最高法院的最终判决。Keown 运用最近邻法和线性模型进行罪名预测。Nagel 通过对案件中存在的变量进行相关性分析，并对罪名进行相应地预测。Ulmer 等使用基于规则的方法分析法律文本数据来帮助法官对事实证据进行分析。然而这些方法都被限制在很少标签的小数据集下，较难推广到一般性案件中。

后来，随着算力的提高，一些基于机器学习的方法被提出，是通过构造特征工程法的方法，利用手工构造的案例特征进行文本分类，并相应地对罪名进行预测。Liu Y H 等人提出一种基于文本挖掘的方法，使用支持向量机（SVM）进行分类。Sulea 利用从文本中提取的案件特征，并使用支持向量机进行罪名预测；Liu 等通过手工提取案例中的词和段落级别的特征，并使用 k 近邻算法（KNN）去预测罪名。但是，这样做的缺点就是这些方法严重依赖手工设计的特征，并且仅限于较小的数据规模和有限的案件类别，并不能当迁移到其他的案件中，模型的泛化性能较差。

近年来，随着神经网络的发展，许多研究者开始利用深度学习技术探索罪名预测任务。Luo 等通过注意力机制来识别案例的事实描述与相关法律条款之间的关系来提高预测性能。Zhong 等基于神经网络模型，并利用有向无环图（DAG）将子任务之间的依赖关系拓扑结构化，能同时完成法律判决预测的多个子任务。jiang 等提出了一种基于深度强化学习的罪名预测模型，利用神经网络与强化学习相结合的方法来提取案件描述中的关键性要素，并提升法律判决预测的性能与可解释性。long 等利用文本阅读理解的方式，对判决进行预测。

二、GAT-Cross-TextCNN 的罪名预测模型


如图所示，本文提出的 GAT-Cross-TextCNN 罪名预测模型主要分为四个部分：

第一部分，案例的图结构数据构建。将数据集中的案例文本进行分词、去停用词等数据清洗工作后，得到案件文本的词库。然后用词库中的词作为节点，用相应的规则来构建边，以此来构建案件的图结构数据。

第二部分，基于 GAT 的图结构信息表示。使用图注意力神经网络对第一部分构建的案件图进行建模，捕获案例的结构信息表示。

第三部分，基于 TextCNN 的文本语义表示。使用文本卷积神经网络（TextCNN）模型捕获案例不同 n -gram 层次的语义信息。

第四部分，特征融合。将案例的结构信息与文本语义信息进行特征融合，并输入到全连接层进行罪名预测。



> 图2 GAT-Cross-TextCNN 罪名预测模型

（一）案例的图结构数据构建

本文所使用的用于构建图结构的数据是基于2018年中国“法研杯”司法人工智能挑战赛（CAIL2018）的司法判决预测数据集的案例事实描述部分。本文选取了在数据集中出现最多的10个罪名。然后将这10个罪名所涉及的案例文本进行分词和去停用词等数据清洗操作。然后，将得到的词按照词频的大小进行统计、排序，选取前一千个词作为词库。对于数据中的每个案例，只保留词库中出现的词，并用这些词作为每个案例图结构数据中的节点。


对于图中的节点，使用 Word2Vec 学习出每个词语的嵌入表示，并将其作为图结构数据中的节点。然后，每一条案例图结构数据的边计算方式如式（1）所示：

$$e_{ij} = \begin{cases} PMI(v_i, v_j), & (v_i, v_j) > 0 \\ 1, & v_i = v_j \\ 0, & \text{其他} \end{cases} \quad (1)$$

e_{ij} 表示图中节点 v_i 与 v_j 之间的边， e_{ij} 的取值范围为大于等于0并且小于等于1。当 $v_i = v_j$ 时 e_{ij} 为1，表示当前节点与自身之间相连一条边。其中 PMI 表示点互信息，其取值在0-1之间，是用来计算词语间的语义相似度。若 PMI 为正则两者之间的语义相关度较高；若 PMI 为负，则表示两者之间的语义相关度较低；若 PMI 为0，则表示两者不相关。PMI 的计算公式为：

$$PMI(v_i, v_j) = \log_2 \frac{P(v_i, v_j)}{P(v_i)P(v_j)} \quad (2)$$

本文所构建的案例图结构数据的可视化样例如图3所示：




> 图3 案例图结构数据样例

（二）基于 GAT 的图结构信息表示

图注意力网络（Graph Attention Network, GAT）能够捕获图结构数据中的局部特性信息，它通过注意力机制（Attention

Mechanism) 来自动学习每个邻居节点的重要程度, 以在进行聚合操作时给不同邻居节点的信息以不同的权重。结合本文构建的案例图结构数据, 本文使用图注意力网络进行建模。



> 图4 图注意力网络中的注意力机制

如图3所示, 图注意力网络在更新图中节点上的信息时引入了注意力机制, 对应的计算公式为:

$$e_{ij} = \text{LeakyReLU}(\alpha^T [W v_i || W v_j]) \quad (3)$$

其中, $||$ 表示向量之间的拼接操作, v_i 表示图中的任意一个中心节点, v_j 表示与该中心节点相连的一阶邻居节点, W 为自定义的一个参数, α 为一个可学习的权重参数, e_{ij} 表示节点 v_j 对于节点 v_i 的重要性程度。激活函数设计为 ReLU。

此外, 为了将这一重要性程度映射到 0-1 的范围内, 我们使用 softmax 函数对上述数值做归一化。得到的结果即为节点 j 对于节点 i 的重要性权重值, 也即注意力系数 a_{ij} 。其计算公式为:


$$a_{ij} = \text{softmax}_j(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{v_k \in N(v_i)} \exp(e_{ik})} \quad (4)$$

得到注意力系数之后, 便可以按照加权求和的思路, 对每一个节点 v_i 的特征向量进行更新。也即如下公式:

$$v_i' = \sigma \left(\sum_{v_j \in N(v_i)} a_{ij} w v_j \right) \quad (5)$$

(三) 基于 TextCNN 的文本语义表示

案例文本的语义表示使用了 TextCNN 模型, 该模型是基于卷积神经网络, 网络结构简单并且擅长抽取文本的不同 n-gram 层次的特征。TextCNN 模型由输入层、卷积层、最大池化层和全连接层组成, 其结构如图5所示:



> 图5 TextCNN 模型结构示意图

模型的第一层为输入层。输入层首先接受由 word2vec 训练好

的每个案例的矩阵表示。该矩阵是一个 $N \times d$ 维的嵌入矩阵 $M \in \mathbb{R}^{N \times d}$ 。其中, N 代表每个案例中词库中词语的个数, d 则代表每个词向量的维度。

模型的第二层为卷积层。在该层中, 用卷积核在文本矩阵上进行上下滑动来提取不同 n-gram 维度的特征。其中, 卷积核 w 为一个矩阵, 其大小为 $w \in \mathbb{R}^{h \times d}$, 其中 h 代表卷积核的高度, 也即 n-gram 的大小; d 代表卷积核的宽度, 也即每个词向量的维度。文选取3个卷积核, 分别为: $w_1 \in \mathbb{R}^{2 \times d}$, $w_2 \in \mathbb{R}^{3 \times d}$, $w_3 \in \mathbb{R}^{4 \times d}$ 。卷积核只在高度上从上到下滑动进行卷积操作, 在宽度和词向量的维度保持一致, 最后得到一个列为1, 行为 $(N-h+1)$ 的特征映射 C , 如下式所示:

$$C = [C_1, C_2, \dots, C_{N-h+1}], \text{dim} \mathbb{R}^{N-h+1} \quad (6)$$

模型的第三层为最大池化层。即为从每个卷积核产生的特征映射中选出最大的一个特征值, 然后将这些选出来的最大特征值拼接起来构成一个最终的特征向量。

模型的最后一层为输出层。在该层中, 首先将最大池化层输出的特征向量通过激活函数进行特征值的筛选, 然后将该特征向量输出。

(四) 特征融合

在 GAT-Cross-TextCNN 中, 图注意力网络会输出一个关于案例图结构信息的特征向量, TextCNN 会得到一个关于案例的语义信息的特征向量。然后, 用交叉注意力机制来融合这两个特征向量, 最终形成一个 d 维的特征向量。然后, 再将其输入到归一化层, 进行归一化操作。最后, 将该特征向量输入到全连接层, 最后输出罪名的预测结果。

三、实验及结果分析

(一) 数据集

为了验证本文提出的罪名预测方法的有效性, 本文在2018年中国“法研杯”司法人工智能挑战赛(CAIL2018)的司法判决预测数据集 CAIL-big 上进行实验。

(二) 对照实验

为了验证本文所提方法的有效性, 选择了4种基线对照模型与本文的模型进行对比。具体分别是:

1. BiLSTM: 使用双向的 LSTM 来获取上下文的信息, 最后用全连接层和 Sigmoid 激活函数作为输出层。

2. TextCNN: 利用多个不同大小的卷积核 捕捉文本上下文中的 n-gram 特征, 通过池化层提取全局信息中的差异化部分实现文本建模。

3. GAT: 利用注意力机制的来自动计算图中相邻节点之间的权重, 并通过聚合操作来更新每个节点的信息。

4. RNN-Attention: 在循环神经网络中引入注意力机制, 以此来自动学习每一部分信息的权重。

(三) 实验评价指标

本文使用准确率、召回率以及 F1 值作为评价指标来进行评估。准确率、召回率以及 F1 值的计算公式分别如公式所示:

$$\text{召回率} = \frac{TP}{TP + FN} \quad (7)$$

$$\text{准确率} = \frac{TP}{TP + FP} \quad (8)$$

$$F1 = 2 \frac{\text{准确率} * \text{召回率}}{\text{准确率} + \text{召回率}} \quad (9)$$

（四）实验结果及分析

GAT-Cross-TextCNN 模型与基线模型的对比实验结果见表1，由表中的结果可以看出，GAT-Cross-TextCNN 模型的准确率、召回率和 F1 值均优于所对比的基线模型，分别达到了 0.9416、0.939、0.9398。实验结果验证了本文提出模型的有效性。

模型	Precision	Recall	F1
TextCNN	0.9380	0.9371	0.9373
GAT	0.9339	0.9272	0.9292
RNN-Attention	0.9129	0.9019	0.9056
BiLSTM	0.9101	0.9054	0.9068
TextCNN- Cross-GAT	0.9416	0.9390	0.9398

表1 不同模型的实验结果对比

（五）结束语

本文针对罪名预测任务，提出了一个新的罪名预测模型：GAT-Cross-TextCNN。该模型同时基于案例的图结构数据和案例文本进行预测，具体而言：构建案例的图结构数据，然后利用图注意力网络进行节点的表示学习，然后再通过 TextCNN 学习每个案例文本不同 n-gram 层次的语义表示。最后，使用交叉注意力机制进行特征融合，并最终输出罪名的预测结果。本文只选取了在数据集中出现最多的是个罪名，没有在整个数据集上进行训练和测试，因此本方法存在一定的限制。在后续工作中，笔者将在全部的数据集上针对全部罪名进行实验验证。

参考文献

[1]C.Liu, C.Chang, J.Ho. Case instance generation and refinement for case-based criminal summary judgments in Chinese[J]. Journal of Information Science and Engineering, 2004, 20(4):783-800.

[2]Xiao CJ, Zhong HX, Guo ZP, Tu CC, Liu ZY, Sun MS. Cai2018: A large scale legal dataset for judgment prediction. 2018. <https://arxiv.org/abs/1807.0247>

[3] 刘宗林, 张梅山, 甄冉冉, 等. 融入罪名关键词的法律判决预测多任务学习模型 [J]. 清华大学学报 (自然科学版), 2019, 59(7):497-504.

[4]Ye H, Jiang X, Luo Z, et al. Interpretable charge predictions for criminal cases: Learning to generate court views from fact descriptions[J], arXiv preprint arXiv, 1802.08504, 2018.

[5]WU Y, KUANG K, ZHANG Y, et al. De-biased court's view generation with causality[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing, 2020:763-780.

[6] 李明超. 论规范性文件不予一并审查: 判断要素及其认定规则——基于 1799 份裁判文书的分析 [J]. 政治与法律, 2021 (4):135-147.

[7]LI S, ZHAO Z, HU R, et al.Analogical reasoning on Chinese morphological and semantic relations[C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics,2018:138-143.